

Abstract

Machine learning, one of the subtitles of artificial intelligence, is a branch of computational algorithms designed to imitate human intelligence by analyzing and learning data through the use of an ability to improve itself. In this way, data are analyzed, and predictions are made about new data. Intelligence simulation is provided with these machines, which are programmed to predict human intelligence and imitate actions. Although machine learning algorithms have been used in many fields thanks to these features, they have not yet been widely used in architecture. In this study, by examining how machine learning is used in architecture currently, it is discussed what consequences can occur in the future with its increased prevalence in the field. In the manuscript, first of all, detailed information about machine learning is given and the working mechanisms of machine learning algorithms are addressed. Later, the uses of machine learning in architecture are discussed, and the potential effects of the studies in this field are examined. Referring to the literature, it is explained how machine learning algorithms are used in different areas in architecture such as recognition of architectural elements, clustering of architectural styles and development of user-driven configurable architectural structures. Finally, by making predictions about the future of the field, potential contributions of machine learning to architecture are evaluated.

Keywords: *Architecture, Artificial Intelligence, Machine Learning, Clustering, Recognition of Architectural Elements*

Özet

Yapay zekanın alt başlıklarından biri olan makine öğrenmesi, verileri analiz edip öğrenerek insan zekasını taklit etmek amacı ile tasarlanan ve kendi kendini geliştirebilme yeteneğine sahip olan bir hesaplama algoritmaları dalı olarak tanımlanmaktadır. Bu sayede veriler analiz edilerek yeni veriler hakkında tahminde bulunmaktadır. İnsan zekasını tahmin etme ve insan eylemlerini taklit etmek amacı ile programlanan bu makineler ile zekâ simülasyonu gerçekleştirilmektedir. Bu özelliği sayesinde pek çok alanda kullanılan makine öğrenmesi algoritmaları, henüz mimarlık alanında yaygın olarak kullanılmamış da bu konuda çeşitli çalışmalar yapılmaktadır. Bu bildiri, makine öğrenmesinin mimarlıkta nasıl kullanıldığını inceleyerek bu teknolojinin yaygınlığının artması ve gelişmesiyle gelecekte ne gibi sonuçlar ortaya çıkacağı konusunu ele almaktadır. Çalışmada, mimarlık alanında makine öğrenmesi algoritmalarının hangi amaçlarla ve ne şekilde kullanıldığı incelenmekte olup makine öğrenmesi uygulamalarının ileride mimariyi nasıl etkileyebileceği üzerinde de durulmaktadır. Metinde ilk olarak makine öğrenmesi hakkında detaylı bilgi verilmekte ve algoritmaların işleyişinden bahsedilmektedir. Daha sonra, mimarlık alanında makine öğrenmesinin kullanım şekillerine değinilerek bu alanda yapılan çalışmaların mimariye etkileri tartışılmaktadır. Konu ile ilgili yapılan araştırmalarda, mimari öğelerin algılanması, mimari stillerin kümelenmesi ve oluşturulan mimari yapıların kullanıcı etkileşimine göre şekillenebilmesi gibi farklı konularda makine öğrenmesi algoritmalarının nasıl kullanıldığı incelenmiştir. Son olarak, mimarlıkta makine öğrenmesinin geleceği hakkında öngörülerde bulunularak makine öğrenmesinin mimarlık alanına sağlayabileceği katkılar değerlendirilmektedir.

Anahtar Kelimeler: *Mimarlık, Yapay Zeka, Makine Öğrenmesi, Kümeleme, Mimari Öğelerin Tespiti*

1. Giriş

Yapay zeka (Artificial Intelligence, AI), bilgisayar programları başta olmak üzere akıllı makineler yapma bilimi ve mühendisliği olarak tanımlanmaktadır (McCarthy, 2007). Burada amaç, insan gibi düşünmek ve eylemleri taklit etmek için makinelerin programlanması ve böylece insan zekasının simülasyonunu sağlamaktır. Öğrenme, akıl yürütme ve algılama yeteneğine sahip olan AI, belirli bir hedefe ulaşmak için en yüksek şansa sahip olan eylemleri rasyonelleştirerek gerçekleştirebilir. Bu noktada bilgisayar programlarının herhangi bir insani etken olmadan otomatik olarak her türlü veriden öğrenebileceği ve bunlara adapte olarak yeni veriler üretebileceği bir sistem olan Makine Öğrenmesi (Machine Learning, ML) algoritmaları geliştirilmiştir. Yapay zekanın alt dallarından biri olan Makine Öğrenmesi, algoritmalar kullanılarak verilerin ayrıştırılabildiği, elde edilen verilerin öğrenilerek bilinçli kararların verilebildiği ve daha sonrasında yeni verilerin oluşturulabildiği bir sistemdir (Grossfeld, 2020). Makine öğrenmesi algoritmalarının kullanılması ile verilerin analiz edilmesi sağlanarak yeni veriler oluşturulurken başarılı tahminlerde bulunulmaktadır.

Makine Öğrenmesi algoritmaları, yapılan veri analizleri sayesinde kendi kendine akıllı kararlar alabilirken, deneyimleri temel olarak otomatik öğrenme ve geliştirme yeteneği de sağlamaktadır (Alpaydın, 2020). Ayrıca, veriler ile yapılması istenen işlemlerin çeşitliliğine bağlı olarak,

verilerin farklı şekillerde işlenmesine olanak sağlayan algoritma çeşitleri bulunmaktadır. Bu algoritmaların otomatik olarak öğrenme ve karar verebilme yeteneği, makinelerin insan faktörü olmadan da çalışabilmesine olanak sağlamaktadır. Verilerin analiz edilmesi ve sayıca fazla olan verilerin yer kaplamadan saklanabilmesi gibi imkanlar kullanıcılara oldukça kolaylık sağlamakta ve işlerin gelişimini desteklemektedir.

Öte yandan, pek çok alanda tercih edilen ve sıklıkla kullanılan makine öğrenimi teknikleri, mimarlık alanında henüz yaygın olarak kullanılmamaktadır. Genel olarak, teknolojik gelişmeleri yakalama ve ayak uydurma konusunda, diğer alanlardan geride ilerleyen mimarlık sektörü, yapay zeka ve makine öğreniminin kullanılarak sektörle bütünleşmesi konusunda da zayıflık göstermektedir. Bu alanda yapılan çalışmalar makine öğrenmesinin mimarlık alanında nasıl kullanılabileceğine ve bu şekilde mimarlık sektörünün gelişimini nasıl etkileyebileceğine dair fikir vermektedir. Mimari projelerdeki öğelerin makineye öğretilmesi ve algoritmaların işlenmesiyle makinelerin mimari öğeleri algılaması, bina-zemin ilişkisi baz alınarak örnek modeller üzerinden makinelerin eğitilerek mimari stillerin kümelenmesi ve yapıların kullanıcı etkileşimine bağlı olarak esnek şekillendirilebilmesi için makine öğrenimi algoritmalarının kullanılması gibi farklı çalışmalar mimarlık sektöründe de makine öğrenmesi algoritmalarının sağladığı imkanları ortaya koymaktadır.

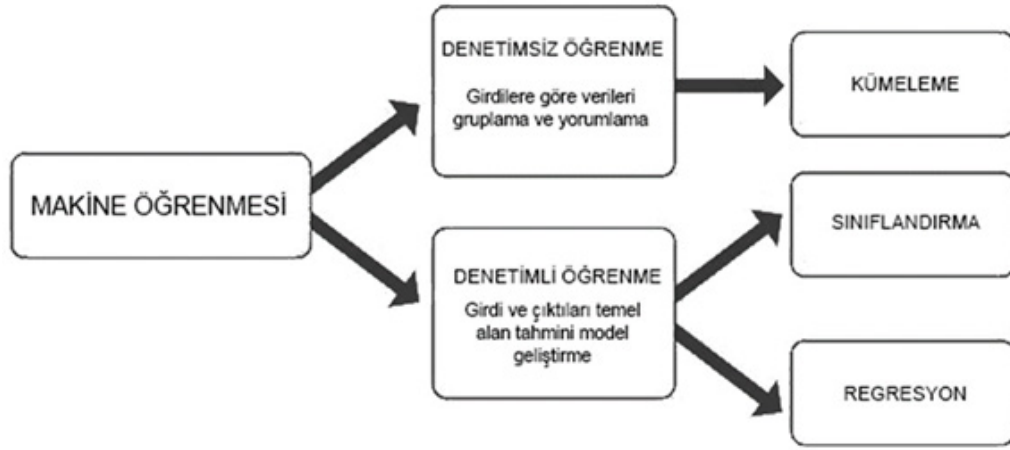
Bu çalışmada, yapay zekanın alt dallarından biri olan makine öğrenmesinin mimarlık alanında nasıl kullanıldığını inceleyebilmek için öncelikle makine öğrenmesinin ne olduğu ve nasıl çalıştığı hakkında bilgi verilmektedir. Makine öğrenmesinde bulunan çeşitli algoritmaların farklı işlemlerde kullanılarak pek çok amaç için uygun bir sistem olduğu anlatılmaktadır. Daha sonra, mimarlık alanında makine öğrenmesi algoritmalarının farklı kullanımları ile ilgili yapılan çalışmalar incelenmektedir. İncelenen kaynaklarda, mimarlık alanında makine öğrenmesi kullanılarak yapılan çalışmalardan elde edilen sonuçlar değerlendirilerek, mimarlık üzerinde makine öğrenmesinin etkileri tartışılmaktadır. Sonuç kısmında, şu an makine öğrenmesinin mimari alanda kullanımı ve etkileri temel alınarak ileriye dönük öngörülerde bulunulmaktadır. Farklı amaçlar için kullanılan makine öğrenmesi algoritmalarının ileride mimarlık alanında yaygın olarak kullanılmasıyla mimarlık sektöründe yaşanabilecek değişiklikler yine bu kısımda irdelenmektedir.

2. Makine Öğrenmesi

Bilgisayar kullanımının dünya genelinde artması ve neredeyse her alanda bilgisayar destekli programların kullanılması ile pek çok veri kayıt altına alınmakta ve istenilen bilgiye ulaşmak için bu verilerin kolay erişilebilir olmasına ihtiyaç duyulmaktadır. Makine Öğrenmesi, örnek veriler ile deneyimleri baz alarak otomatik öğrenme gerçekleştiren ve bu şekilde

gelişim sağlayan bilgisayar algoritmalarının kullanıldığı bir sistemden oluşmaktadır (Alpaydın, 2010). Bu sistem, her türlü verinin daha etkin olarak işlenebilmesi ve verilerin analizlerini yaparak ileriye dönük doğru tahminler yapabilmek için kullanılmaktadır. Öncelikli olarak yapılacak istenen işlem için hangi algoritmanın kullanılacağı belirlenmektedir. Farklı algoritma çeşitleri, makine öğrenmesinin alt dallarının oluşmasını sağlamaktadır (Şekil 1). En yaygın kullanılan makine öğrenmesi türleri, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenmedir (Zhang, 2010). Bu çeşitlilik sayesinde kullanıcıların istedikleri sonuca ulaşmalarında en uygun algoritmaların kullanılması sağlanmakta ve elde edilen sonuçtan maksimum verim alınması amaçlanmaktadır.

Makine öğrenmesinin en yaygın kullanılan tekniği olan denetimli öğrenmede, makinenin eğitilebilmesi için etiketler kullanılmaktadır. Bu sistemlerde makinenin araması için gerekli olan kalıpların belirlenebilmesi amacıyla girdi olarak yüklenen verilerin etiketlenmesi gerekmektedir (Hao, 2018). Girdi olarak yüklenen veriler makineye tanıtarak etiketleme işlemi gerçekleştirilmekte ve makinenin öğrenmesi sağlanmaktadır. Öğretilen bilgilere göre çıktılar istenilen kategoriye uygun olarak analiz edilmektedir. Böylece, yapılan etiketleme doğrultusunda makinenin yeni girdileri sınıflandırması ve ayrıştırması da mümkün olmaktadır. Denetimli öğrenme, genellikle sınıflandırma ve



Şekil 1 Makine Öğrenmesi Teknikleri (Deland, 2018)

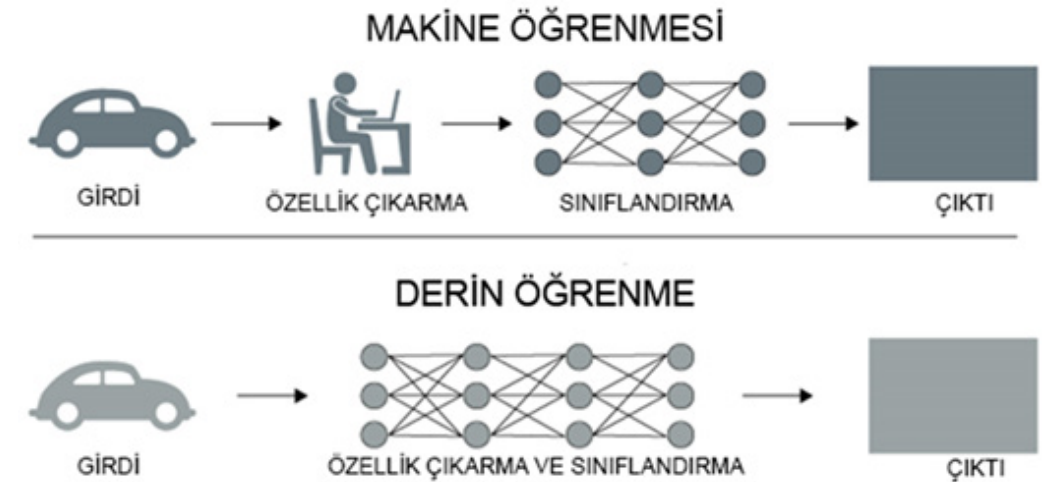
regresyon işlemleri için kullanılmaktadır. Sınıflandırma işleminde girdi olarak yüklenen tüm veriler makineye tanıtılmakta ve makineye kategorize edilerek aktarılmaktadır. Böylece makinenin verileri ne şekilde sınıflandırması gerektiği öğretilecek daha sonra yüklenen verilerin aynı şekilde sınıflandırılması sağlanmaktadır. Regresyon işleminde ise örnek veriler kullanılarak yeni verilerin sonuçları tahmin ettirilmektedir. Denetimli öğrenmede, makineye tanıtılan örnek verilerin fazla olması, elde edilecek olan sınıflandırma ve tahmin sonuçlarının doğru olmasında etkin bir rol oynamaktadır. Girdi olarak yüklenen verilerin tanıtılmasına bağlı olarak yapılan etiketleme işlemi denetimsiz öğrenme türünde yapılmaktadır (Hao, 2018). Makineye yüklenen veriler üzerinde herhangi bir etiket bulunmaması makinenin yüklenen veri üzerinden elde edeceği bilgiyi kısıtlamayı önlemektedir. Bu öğrenme türünde makineye nasıl öğrenmesi gerektiği söylenmeden

makinenin kendi kendine öğrenmesi hedeflenmektedir (Zhang, 2010). Burada verilerin sahip oldukları benzerliklerine göre gruplandırma yapılmaktadır. Bu işlem kümeleme olarak adlandırılmaktadır (Gavriloya ve Stryungis, 2020). Kümeleme işlemi sayesinde, herhangi bir sınırlama olmadan sadece verilerin benzerlikleri baz alınarak ayrıştırma yapılabilmektedir. Makine öğrenmesi, denetimsiz öğrenme türü ile günlük hayatta kullandığımız öneri sistemleri, sosyal medya yayınları ve ses yardımcıları gibi pek çok programda aktif rol oynamaktadır. Bunlardan en yaygın kullanılanları Youtube, Netflix, Spotify, Facebook, Twitter, Siri ve Alexa uygulamalarıdır (Hao, 2018). Bu uygulamalarda denetimsiz öğrenme ile kullanıcı tercihlerinin girdi olarak kaydedilmesi ve bu girdiler ile benzerlik gösteren verilerin kullanıcılara yöneltilmesi sağlanmaktadır. Böylece kişilere en uygun öneriler yapılabilmektedir. Pekiştirmeli öğrenme ise, algoritmaların yararlarını ve sınırlarını

anlayarak geliştirilmesini amaçlayan bir makine öğrenimi yaklaşımıdır (Szepesvari, 2010). Bu tür öğrenme uygulamalarında geri bildirimli algoritmalar kullanılarak pekiştirmeli öğrenme yapılmaktadır. Genellikle robotik alanlarda kullanılan bu öğrenme türü ile öğreticiye ihtiyaç duymadan otomatik olarak kendi kendine öğrenme ve geliştirme sağlanmaktadır. Makine öğrenmesinin ana alt başlıklarından bir tanesi de derin öğrenmedir. Derin öğrenme, yapay sinir ağlarının kullanıldığı ve birden çok katmandan oluşarak verilerin yapılandırılmasını güçlendiren ve böylece gizli katmanların daha sağlam özellikler keşfetmelerini amaçlayan bir öğrenme modelidir (Wang, Ma, Zhang ve ark, 2018). Derin öğrenmede bulunan çoklu katmanlar ile verilerin pek çok kez işlenmesi sağlanmaktadır. İlk başta girdi olarak yüklenen bir verinin her bir katmana yeni bir veri gibi geçerek tekrar tekrar işlenmesi ile herhangi bir insan etkisi

olmadan, otomatik olarak verilerden öğrenme işlemi gerçekleşmektedir. Bu noktada, derin öğrenmede kullanılan yapay sinir ağları ile uçtan uca öğrenme yöntemi kullanılırken manuel bir işleme gerek duyulmaması, makine öğrenmesi ile derin öğrenme arasındaki en büyük fark olarak değerlendirilmektedir (Şekil 2). Derin öğrenme, insan zekasından esinlenerek oluşturulmuş bir öğrenme türüdür ve beyindeki sinir ağlarını taklit eden katmanlı sinir ağlarından oluşmaktadır. Buradaki katmanların verileri tekrarlayan bir biçimde işlemesi ile kendi kendine akıllı kararlar alabilen ve bu kararları uygulayabilen bir sinir ağı oluşturulmaktadır (Gavriloya ve Stryungis, 2020). Bu sayede derin öğrenme algoritmaları, oluşturulan bir tahminin doğruluğunu kendi sinir ağı üzerinden belirleyebilmektedir.

Şekil 2. Makine Öğrenmesi ve Derin Öğrenme (Shah, 2018).



3. Mimarlıkta Makine Öğrenmesi


Mimarlık sektörü teknolojik gelişmeleri takip etmede ve bu değişikliklere ayak uydurarak gelişim göstermede mühendislik alanlarına göre geriden gelen bir alan olsa da değişen çevrenin şartlarına ayak uydurmak için yeni düzene uyum sağlamayı da başarabilen bir sektördür. Bilgisayar programlarının gelişmesine bağlı olarak hayatın her noktasında bu programların kullanılmaya başlanması, mimarlık alanında da mecburi bir dijitalleşmeye sebep olmuştur. El çizimlerinin yerini öncelikle 2B çizim programları ve daha sonra programların gelişmesiyle birlikte de 3B görselleştirme programları almıştır. Günümüzde ise mimarlık alanında kullanılan makineler ile çizim yapmanın yanı sıra, farklı disiplinlerin ortak bir platformda birbirleri ile etkileşimli olarak çalışmalarına olanak sağlayan çevrimiçi programlar da kullanılmaktadır. Öte yandan, mimarlık, inşaat ve mühendislik sektöründe, açıkça görülebilir bir şekilde, yenilikçi teknolojileri çalışma ortamlarına kabul etme isteksizliği bulunmaktadır (Brown ve diğ., 2020). Alışlagelmiş olan çalışma sistemini bırakarak yeni bir düzen kurmak pek kolay olmadığından şu an çok az mimarlık ofisinde bu şekilde etkileşimli bir çalışma ortamı oluşturulabilmiştir. Mimarlık alanında yeniliklere ayak uydurma konusunda yaşanan bu sıkıntılara rağmen bir yandan da yeni gelişmelerin mimari alana uyarlanması ile elde edilebilecek fırsatların değerlendirilmesi amacıyla çalışmalar yapılmaktadır. Makine

öğrenmesinin mimarlık sektörü üzerine katkılarını inceleyebilmek için mimarlıkla ilişkili farklı konularda makine öğrenmesi uygulamaları da araştırılmaktadır. Mimarlıkta kullanılan makine öğrenmesi yöntemlerinden biri kümelemedir. Kümeleme, bir dizi benzer nesneyi küme adı verilen aynı grupta toplama görevidir. Alymani, Jabi ve Corcoran (2020) bina-zemin arasındaki ilişkiyi anlamak ve bina tasarımı stillerini belirleyebilmek için makine öğrenmesinin alt dallarından biri olan denetimsiz öğrenmenin sağladığı kümeleme yönteminin kullanıldığı bir araştırma yapmıştır. Bu çalışmada kümeleme yöntemi ile mimarın tarzını bina-zemin arasındaki ilişkiye göre ele alarak kapsamlı bir veri tabanı oluşturmak hedeflenmektedir. Böylece, yapıların belirli tarihsel dönemlere, bina türlerine ve bölgelere ait anlamsal gruplar halinde sınıflandırılmasına olanak sağlanabilecektir (Alymani, Jabi ve Corcoran, 2020). Yapılan araştırma kapsamında, farklı mimari tarzların figür-zemin ilişkisini anlayabilmek için, bir mimari tanım çerçevesi oluşturmak gerekmektedir. Böyle bir çalışma için son zamanlarda gelişme gösteren ve girdi olarak görsellerin alındığı görüntü işleme kullanılan derin evrişimli sinir ağlarının (DCNN) kullanılması önerilmiştir (Obeso ve diğ., 2016). 139 mimari emsal alınarak yapılan bu çalışmada, ilk olarak mimari örnekler toplanmış ve daha sonra modernizm, postmodernizm ve çağdaş mimari olmak üzere tarihteki üç belirli dönemin konut binalarına odaklanılmıştır. Bu programda modelin

kategoriler arasında doğal bir sıralama yapmasını sağlamak amacıyla kategorik verilerin sayısal verilere dönüştürüldüğü tek sıcak kodlama yöntemi kullanılmıştır. Bu kodlama yönteminde, var olmayan bir kategori için '0' kullanılırken mevcut bir kategoriye belirtirken '1' kullanılarak verilerin sayısallaştırılması sağlanmıştır. Yapılan kümelemede, zemine tam oturan binalar bir grup olarak ayrıştırılırken binaların zeminden yükseltilmesine bağlı olarak diğer sınıflandırmalar yapılmıştır (Şekil 3). Araştırmanın sonucunda, mimarların zemine yaklaşımları aracılığıyla stillerini anlayabilmek için daha fazla veri toplanması gerektiği anlaşılmış olsa da makine öğrenmesinin bina ile zemin arasındaki ilişkiyi farklı mimarların nasıl tasarladığını otomatik olarak keşfetmeyi sağlayan yeni bir konsept iş akışı önerilmiştir. Bu çalışmanın, denetimsiz öğrenmenin mimari-Makine öğrenmesinin mimarlık alanında


kullanılmasında uygulanan bir diğer yaklaşımda ise, çizimleri ve görselleri yapay sinir ağları tarafından algılayarak, kat planı çerçevesinde bu öğeleri otomatik olarak sınıflandıran ve her bir odanın özelliklerini tanımlayabilen bir makine öğrenimi formu tanıtılmaktadır. Bu yaklaşımda temel olarak makine öğrenmesinin, diğer sektörlerdeki kazanımları düşünülerek, mimari alana da adapte edilmesi gerektiği öne sürülmektedir (Brown ve diğ., 2020). Bu amaçla yapılan çalışmada, evrişimli sinir ağları (CNN) kullanılarak mimari çizimleri okuma ve etiketleme uygulaması yapılmıştır. CNN ile görüntü analizi yapılırken doğru yönlendirme ve eğitime sayesinde, tasarımların mimari bir çerçeve içerisinde anlamlandırılması ve yorumlanması mümkün kılınmaktadır. CNN'ler, ilk olarak piksel düzeyindeki görüntüler üzerinde evrişimsel işlemler uygulayarak öznelikleri tespit

Şekil 3. Farklı Bina-Zemin İlişkisine Gruplarındaki Mimari Stillerin Kümelmesi (Alymani, Jabi ve Corcoran, 2020).



etmekte ve daha sonra tespit edilen bu özniteliklerin anlaşılmasını geliştirerek özelliklerin sonraki katmanlarda sınıflandırılmasını sağlamaktadır (Brown ve diğ., 2020). Kullanılan yapay sinir ağlarının en doğru sonucu verebilmesinde, girdi olarak yüklenen örneklerin çokluğu oldukça önemlidir. Makinenin öğrenebilmesi ve algılayarak karar verebilmesi için farklı örneklerden oluşan geniş bir veri kümesi oluşturulması gerekmektedir. Mimari çizimlerin algılanabilmesinde mekanlardaki yatak odası kelimesi gibi metinlerin, yatak görseli gibi sembollerin ve oda sınırları ile zeminler gibi ikonların yapay sinir ağlarına tanıtılmasıyla, makine, odaları birbirinden ayırıştırabilecek şekilde eğitilmektedir (Şekil 4). CNN'lerin mekanları algılayarak ayırıştırabileceği kanıtlanmış olsa da 454 kat


planı kullanılarak gerçekleştirilen çalışmada, veri kümesinin darlığı sebebiyle banyo ve çamaşır odası gibi mekanların tam ayırt edilememesi gibi sorunlarla karşılaşmıştır. Bu durum daha fazla örnek kullanılması ile makinenin eğitiminin geliştirilmesi gerektiğini ve mekan ayrımlarını yaparken daha doğru sonuçlar elde etmenin veri çokluğuna bağlı olduğunu da ispatlamıştır. Bu araştırmaya benzer olarak, kesitler ve planlar arasında ayırım yapabilmek amacıyla CNN'lerin kullanılması (Ng, 2018), mimari çizimleri sınıflandırma, doğrulama ve oluşturma için makine öğreniminin kullanılması (Chaillou, 2019) ve yapay sinir ağları kullanılarak mimarlar arasında tasarımların ayırt edilmesi gibi farklı çalışmalar da yapılmıştır. Tüm bu çalışmalar, yapay sinir ağları ile mimarlık alanında



Şekil 4. Çeşitli Oda Etiketleme Sonuçları (Brown ve diğ., 2020)

daha fazla makine öğrenimi araştırmalarına ve uygulamalarına yatırım yapılması gerektiği düşüncesini desteklemektedir. Mimari yapılarda kullanıcı isteklerine göre interaktif ve etkileşimli bir biçimde çevreyle ilişkili tasarımlar yapılabilmesi için makine öğrenmesi uygulamalarının kullanılmasıyla ilgili araştırmalar da bulunmaktadır. Bu araştırmalarda, mimarlık alanında makine öğrenmesinin kümeleme, algılama ve ayırıştırma işlemleri dışında kullanıcılara bağlı olarak değişiklik gösterebilen mekanlar yaratabilmek amacıyla da kullanılabileceği belirtilmektedir. Uyarlanabilir esnek mekanlar yaratma fikri yeni bir fikir olmamakla beraber bu sistemin işleyebilmesi için pek çok farklı proje yapılmıştır (Escrig Pallares ve diğ., 1996). Günümüzün getirdiği dijitalleşme hareketinin bu tarzdaki projelerde kullanılabilmesi amacıyla kullanıcıların fiziksel olarak inşaat ve mekânsal ayarlamalara katılımına olanak sağlayan Tanımlama ve Montajlama için Öğrenme (LTDA) metodu kullanılmaktadır. LTDA metodunun kullanılabilmesi için hesaplamalı modelle tanımlanan mekânsal düzenlemelerin

bulunması gerekmektedir. Hosmer & Tigas (2019), derin öğrenme tekniklerini makine öğrenmesi ile birlikte kullanarak bir hesaplama şablonu geliştirmişlerdir (Bus, 2020). Bu şablonu UNITY adı verilen bir oyuna adapte ederek mekânsal geometrik senaryo üretmeyi amaçlamışlardır. Makine öğrenmesindeki öğrenme süreci Tensorflow adlı bir platform üzerinden, önceden tanımlanmış bilgi yığınları tarafından beslenmektedir. Böylece, bilgi yığınları son kullanıcıdan çıkartılabilmüş ve sistem tercih edilen çözümlerden öğrenerek yeni mekânsal senaryolar üretebilmiştir (Şekil, 5). Bahsedilen çalışmada yapının yardımcı ilkelerinin davranış testi hesaplamalı olarak yapılarak, modeldeki basit birimlerin davranış özelliklerini anlamlandırmak ve son kullanıcılar tarafından ileriye dönük olası mekan senaryolarını sunmak hedeflenmiştir. Bu çalışmadaki veri kümelerinin, araştırmanın devamı için kullanılacak olan TensorFlow platformunda çalışan derin öğrenme yöntemini test etmede kullanılabileceği düşünülmektedir (Bus, 2020). Araştırma, kullanıcıların



Şekil 5. Kule Montajlarındaki Yapılandırılabilir Birimler ve Yeni Mekansal Deneyimler (Bus, 2020)

taleplerine daha kapsamlı yanıt veren, akıllı bileşenlerle çalışan ve kullanıcı odaklı montaj süreçlerine odaklanarak bu yönergelerin de takip edildiği bir çalışma ortamına da zemin hazırlamaktadır. Aynı zamanda, mimarlık alanında makine öğrenmesi uygulamalarının bu şekilde ileriye dönük olası modelleri değerlendirmek için kullanılması mimarlık alanındaki diğer gelişmelere de katkı sağlayacaktır.

4. Tartışma ve Sonuç

Makine öğrenmesi, sahip olduğu algoritmalar ve yapay sinir ağlarının etkin kullanımı sayesinde, veri depolama ve çok sayıda veriyi analiz ederek kullanıcıların istedikleri bilgiye ulaşmalarında kolaylık sağlayan bir sistem haline gelmiştir. En temel tabiriyle verilerden öğrenme olarak tanımlanabilen makine öğrenmesi, örnek verileri kullanarak ayrıştırma, kümeleme ve sınıflandırma gibi işlemleri yapabilirken aynı zamanda kendi kendine karar vermeyi sağlayan yapay sinir ağları ile de örnek verilerden farklı olarak yeni çıkarımlar üretebilmektedir. Mimarlık alanında kullanılmaya başlanan makine öğrenmesi uygulamaları ile elde edilebilecek fırsatları değerlendirebilmek adına yapılan çeşitli çalışmalar, makine öğrenmesinin mimaride daha yaygın bir şekilde kullanılması için bir temel oluşturmaktadır. Bina-zemin arasındaki ilişkileri analiz ederek mimarların yaklaşımlarını tahmin edebilme ve mimari stillerini anlamaya olanak sağlayan araştırmanın, makine öğrenmesi kullanımının ilerletilmesi ile

birlikte, gelecekte yapılacak olan binalar hakkında da öngörülerde bulunmamıza imkan sağlayabileceği düşünülmektedir (Alymani, Jabi ve Corcoran, 2020).

Ayrıca, denetimsiz öğrenme kullanılarak yapılan kümeleme işleminin mimari verileri analiz etmede ne şekilde kullanıldığı incelenerek, bu alandaki farklı çalışmaları geliştirmek için de bu yöntemin kullanılabilir olduğu anlaşılmaktadır. Bir diğer çalışma olan mimari öğelerin algılanmasında kullanılan makine öğrenimi sistemi ise mekan tanımını ve ayrıştırmasını yapabilen algoritmaların başarılı bir şekilde çalıştığını göstermektedir (Brown ve diğ., 2020). Bu algoritmaların büyük ölçüde veri kümeleri ile eğitilmesi sonucu ileride yeni mekan tasarımları oluşturulabilmesi de mümkün gözükmektedir. İncelenen diğer çalışmada bahsedilen kullanıcı ile etkileşimli olarak uyarlanabilen mekanlar yaratmak için makine öğrenimi yöntemlerinin kullanılması ise mimarlık alanında ortaya çıkabilecek olası binlerce ihtimali değerlendirebilmeyi hedeflemektedir (Bus, 2020). Hesaplamalı olarak oluşturulan modeller üzerinde yapılan çalışmalar ile oluşturulan birimlerin çeşitli varyasyonlarla bir araya gelmesine olanak sağlayan bu sistem ile tasarımdaki engellerin kaldırılması da sağlanmış olmaktadır.

Mimari çizimleri anlayarak yeni plan üretmenin yanı sıra, teknik çizimlerdekihataların tespit edilmesi ve otomatik olarak düzeltilmesi için de makine öğrenmesi algoritmaların geliştirilmesi mümkündür. Bir projeye başlarken vaktin büyük bir

kısımında araştırma ve veri toplama yapılması, tasarım için ayrılan zamanın azalmasına sebep olmaktadır. Makine öğrenmesi algoritmaları ile projenin ihtiyaçlarına ve içerik bilgisine göre farklı kavramsal fikirlerin, mimarın önceden tanımladığı kelime havuzu kullanılarak yakalanabileceği düşünülmektedir. Böylece yakalanan kavramsal fikirlerin yazılı veya görsel olarak tanımlanmasında makine öğrenmesi yöntemlerinin kullanılarak tasarım konseptlerinin geniş bir şekilde ve daha az zaman harcayarak ele alınabileceği ileri sürülmektedir. Bu olasılıklar değerlendirildiğinde ise, makine öğrenimi ile bilgilerin sentezlenmesi, fikirlerin özetlenmesi ve bu fikirlerden çıkarımlar yapılarak tasarım özelliklerinin kodlanabileceği ihtimali üzerinde durulmaktadır (Belem, Santos ve Leita, 2020). Mimarların zaman alan ve karmaşık görülen işlemlerin kolaylaştırılmasında makine öğrenmesi uygulamalarını kullanmaları ile tasarımlara daha fazla zaman ayırabileceği de göz önüne alınmalıdır. Aynı zamanda, makine öğrenmesi algoritmalarının eğitildiği veriler sayesinde sistemin zamanla kendini geliştirerek mimari tasarımlar için de önerilerde bulunması mümkün görülmektedir. Karar verme aşamasında tasarımcıya fikir vermek ve farklı alternatifleri değerlendirerek en uygun olanını seçmede kullanılabilecek olan bu algoritmaların tasarımcının işinikolaylaştırması da oldukça mümkün görülmektedir. Sonuç olarak makine öğrenmesi henüz mimari alanda yaygın olarak kullanılmıyor

olmasına rağmen, bu alandaki araştırmaların artması ve yapılan çalışmaların geliştirilmesiyle mimarlık alanının daha ileri bir noktaya taşınacağı anlaşılmaktadır. Bu teknoloji sayesinde mimarlık alanında yaşanan teknik sorunlara kısa sürede ve daha doğru çözümler bulunabileceğine inanılmaktadır. Öte yandan bu sistemin kullanımının yaygınlaşmasının ve süreklilik kazanmasının kolay olmayacağı da açıkça görülmektedir. Alışlagelmiş düzeyin getirdiği kalıplara bağlı kalmanın ve yenilikçi sistemlerin getirdiği belirsizliklerden uzak durmanın sonucu olarak mimarlık alanının teknolojik gelişmelerde geri kaldığı inkar edilemez bir gerçektir. Bu durumun değiştirilebilmesi ve mimarlığın daha ileri boyutlara taşınabilmesi için makine öğrenmesinin sunduğu imkanlardan yararlanılması ve bu konu hakkında daha çok çalışma yapılması gerekmektedir.

KAYNAKÇA

Alpaydin, E. (2010). Introduction to Machine Learning, Second Edition. The MIT Press: Cambridge, Massachusetts.

Alymani, A., Jabi, W., & Corcoran, P. (2020). Machine Learning Methods for Clustering Architectural Precedents. Proceedings of the 38th eCAADe Conference, pp. 643-652.

Belém, C., Santos, L., & Leitão, A. (2019). On the Impact of Machine Learning: Architecture without Architects. Proceedings of the CAADFuture19 Conference, pp. 274-293.

Brown, L., Yip, M., Gardner, N., Haeusler, M. H., Khean, N., Zavoleas, Y., & Ramos, C. (2020). Drawing Recognition: Integrating

Machine Learning Systems into Architectural Design Workflows. Proceedings of the 38th eCAADe Conference, pp. 289-298

Buš, P. (2020). User-driven Configurable Architectural Assemblies: Towards Artificial Intelligence-embedded Responsive Environments. Proceedings of the 38th eCAADe Conference, pp. 483-490.

Chaillou, S. (2019). AI + Architecture | Towards a New Approach, Master's Thesis, Harvard University

Escrig Pallares, F, Pérez-Valcárcel, J and Sánchez- Sanchez, J (1996). 'Las cubiertas desplegables de malla cuadrangular', Boletín Académico de la ETSA de La Coruña, 20, pp. 37-46

Gavrilova, Y., Stryungis, R. (2020, July 11). Machine Learning: Algorithm Classification Overview. Serokell. <https://serokell.io/blog/machine-learning-algorithm-classification-overview>

Grossfeld, B. (2020, Ocak 23). Deep learning vs machine learning. Zendesk. <https://www.zendesk.com/blog/machine-learning-and-deep-learning/>

Hao, K. (2020, Nisan 02). What is machine learning? <https://www.technologyreview.com/2018/11/17/103781/what-is-machine-learning-we-drew-you-another-flowchart/>

McCarthy, J. (2004). WHAT IS ARTIFICIAL INTELLIGENCE? 14. https://homes.di.unimi.it/borghese/Teaching/AdvancedIntelligentSystems/Old/IntelligentSystems_2008_2009/Old/IntelligentSystems_2005_2006/Documents/Symbolic/04_McCarthy_whatissai.pdf

Ng, J.M.Y., Khean, N., Madden, D., Fabbri, A., Gardner, N., Haeusler, M.H .and Zavoleas, Y. (2019). Optimising Image Classification - Implementation of Convolutional Neural Network Algorithms to Distinguish Between

Plans and Sections within the Architectural, Engineering and Construction (AEC) Industry, Proceedings of the 24th CAADRIA Conference, pp. 795-804

Obeso, A., Benois-Pineau, J., Acosta, A. and Vázquez, M. (2016). Architectural Style Classification of Mexican Historical Buildings Using Deep Convolutional Neural Networks and Sparse Features, Journal of Electronic Imaging, 26, p. 011016

Shah, J. (2018, Ağustos 28). What is the difference between deep learning and usual machine learning? Quora. <https://www.quora.com/What-is-the-difference-between-deep-learning-and-usual-machine-learning/answer/Jay-Shah-244>

Szepesvári, C. (2010). Algorithms for Reinforcement Learning. <https://www.morganclaypool.com/doi/abs/10.2200/S00268ED1V01Y201005AIM009>

Wang, J., Ma, Y., Zhang, L., Gao, R., & Wu, D. (2018, Ocak 08). Deep learning for smart manufacturing: Methods and applications. https://www.sciencedirect.com/science/article/pii/S0278612518300037?casa_token=6zOJnA7cWHEAAAAA%3AZTk-1yfg_Us7eH-ycJahKHe8EpRxT88KWsjft-jDK_5SnUpXGfrtp2YrLQwiplj9_CJO6udxzRhM

Zhang, Y. (2010, Şubat 01). New Advances in Machine Learning. <https://www.intechopen.com/books/new-advances-in-machine-learning>